



HOG기반 RBFNN을 이용한 상반신 검출 시스템의 설계

Design of Upper Body Detection System Using RBFNN Based on HOG Algorithm

김선환* · 오성권*[†] · 김진을**

Sun-Hwan Kim, Sung-Kwun Oh[†], and Jin-Yul Kim

*수원대학교 전기공학과, **수원대학교 전자공학과

^{*}Department of Electrical Engineering, The University of Suwon

^{**}Department of Electronic Engineering, The University of Suwon

요약

최근 감시와 보안을 목적으로 활발하게 CCTV가 설치되고 있고, 지능형 감시시스템은 영상에서 객체의 검출 및 감시 등으로 광범위하게 응용되고 있다. 본 연구에서는 지능형 영상 감시 시스템에서 HOG 특징과 FCM 기반의 RBFNN 분류기를 이용한 상반신 검출 방법을 제안한다. HOG는 보행자를 검출하기 위해 기존에 제안되었던 특징으로 본 논문에서는 이를 사용해 상반신의 고유한 기술기를 학습하였다. HOG 특징은 입력 이미지의 크기에 비례하는 고차원의 특징 벡터로 기술기를 표현하기 때문에 RBFNN분류기의 입력데이터로 쓰려면 차원 축소가 필요하다. 이를 위해 PCA 알고리즘을 RBFNN 분류기 앞에 적용하여 HOG 특징의 차원을 저차원으로 축소하였다. 컴퓨터 실험에서는 미리 분류된 상반신 영상과 사람이 아닌 영상을 통해 분류기를 훈련시킨 후 테스트 영상과 동영상에 이용하여 제안된 상반신 검출 방법의 성능을 평가하였다.

키워드 : 상반신 검출, HOG, PCA, 패턴분류기, FCM-based RBFNNs

Abstract

Recently, CCTV cameras are emplaced actively to reinforce security and intelligent surveillance systems have been under development for detecting and monitoring of the objects in the video. In this study, we propose a method for detection of upper body in intelligent surveillance system using FCM-based RBFNN classifier realized with the aid of HOG features. Firstly, HOG features that have been originally proposed to detect the pedestrian are adopted to train the unique gradient features about upper body. However, HOG features typically exhibit a very high dimension of which is proportional to the size of the input image, it is necessary to reduce the dimension of inputs of the RBFNN classifier. Thus the well-known PCA algorithm is applied prior to the RBFNN classification step. In the computer simulation experiments, the RBFNN classifier was trained using pre-classified upper body images and non-person images and then the performance of the proposed classifier for upper body detection is evaluated by using test images and video sequences.

Key Words : Upper body detection, HOG, PCA, Pattern classifier, FCM-based RBFNNs

Received: May, 23, 2016

Revised : Aug. 11, 2016

Accepted: Aug. 11, 2016

[†]Corresponding authors

ohsk@suwon.ac.kr

1. 서론

최근 보안을 목적으로 CCTV의 설치는 매년마다 증가하면서 영상을 지능적으로 분석하는 기법 및 방법에 대한 연구가 많이 진행되고 있다. 이러한 영상 내에서 객체의 검출은 지능형 CCTV 시스템에 있어서 기본적인 기술이지만 형태와 조명에 대한 변화와 장애물 등의 방해요소를 고려해야 되는 매우 어려운 기술이기도 하다. 객체를 검출하기 위해서는 배경에 대한 정보를 이용하는 방법과 특징(feature) 또는 특징점(interest point)을 활용하는 방법이 있다. 객체를 검출하는 방법 중 하나인 HOG(Histogram of Oriented Gradient) 알고리즘은 보행자를 검출하기 위한 알고리즘으로 2005년에 제안되었다[1][2][5]. HOG 알고리즘은 보행자뿐만 아니라 차량 검출에도 사용되며 신체의 일부를 찾아낼 때에도 많이 응용되고 있고 본 논문에서는 감시용 영상에서 사람의 전신이 나오지 않을 경우, 객체를 검출하기 위한 HOG 기반 상반신 검출 시스템을 제안한다.

상반신은 기본적으로 전면을 기준으로 오메가(ω)의 형태를 띠고 있지만 대상의 옆모습과 머리

본 연구는 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF-2015R1 A2A1A15055365) 그리고 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음[GRRC 수원2016-B2, U-city 보안감시 기술협력센터]

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

모양에 의해 일정하지 않은 형태를 띠고 있다는 특징이 있다. 앞모습 외에 후면과 측면에 대해서도 검출 할 수 있도록 학습데이터를 구성하였다. 또한 긴 머리를 가진 대상에 의한 오검출을 줄이기 위해 다양한 상반신의 이미지도 데이터셋에 추가하였다. 먼저, 상반신을 검출하기 위해 HOG를 이용하여 특징을 추출하였고 분류하기 위해 FCM 기반 RBFNNs 패턴분류기를 사용하였다[3][4][6]. 머리부터 어깨까지의 영역을 위주로 구성된 대부분의 이미지는 HOG 특징으로 변환시키고 고차원의 특징을 차원 축소 알고리즘으로 축소시킨 후 패턴분류기를 이용하여 상반신을 검출한다.

검출시스템의 성능을 평가하기 위해 수원대학교 IC&CI 연구실에서 촬영한 동영상과 임의의 사진 100장을 사용하여 결과를 나타내었다.

2. 상반신에 대한 특징 데이터 추출

2장에서는 상반신에 대한 특징 추출 방법에 대해 설명한다. 본 논문에서는 기울기를 이용한 HOG 알고리즘을 통해서 상반신에 대한 특징을 추출하게 된다. 또한 고차원의 HOG 특징을 패턴분류기의 알맞게 저차원으로 축소시키는 PCA 알고리즘을 살펴본다. 아래의 그림 1은 시스템의 전반적인 개요를 도시하였다.

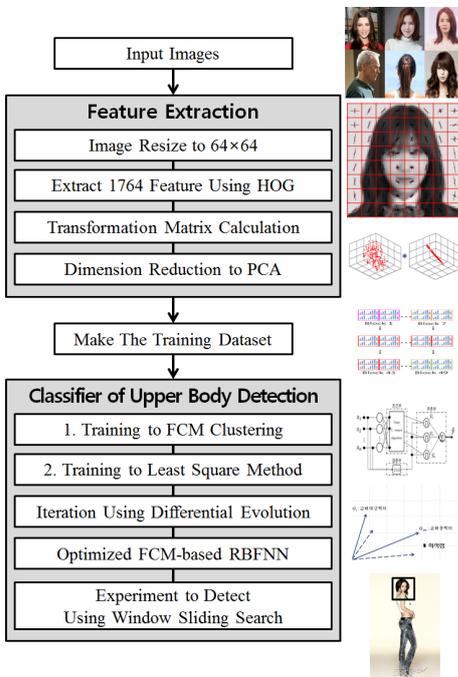


그림 1. 상반신 검출 시스템의 개요
Fig. 1. Outline of upper body detection system

2.1 Histogram of Oriented Gradient

HOG는 보행자를 검출하기 위해 2005년에 Dalal과 Triggs에

의해 제안된 알고리즘으로 국소영역에서 근접화소들 간에 밝기 차이를 이용하여 방향성을 구하고 히스토그램으로 구성하여 벡터로 표현한다. HOG 특징은 아래의 단계로 추출된다.

먼저 기울기 값은 입력영상 $I(x,y)$ 으로부터 x축(가로)과 y축(세로)의 변화에 대해 f_x 와 f_y 를 계산하고, 이를 통해 기울기 G 와 방향성 θ 를 구한다.

$$f_x(x,y) = I(x+1,y) - I(x-1,y)$$

$$f_y(x,y) = I(x,y+1) - I(x,y-1)$$

$$G(x,y) = \sqrt{f_x(x,y)^2 + f_y(x,y)^2}$$

$$\theta(x,y) = \tan^{-1}\left(\frac{f_y(x,y)}{f_x(x,y)}\right)$$

입력 영상을 cell과 block로 분할한다. 영상을 cell이란 작은 구역으로 나누게 되는데 아래의 그림과 같이 정의된 cell이 일정 개수로 모여서 block 단위로 이루어진다. 본 논문에서는 알고리즘에서 제안한 보행자 검출 연구에서 사용된 cell은 8×8 [pixels], block은 2×2 [cells]로 동일하게 구성하였다.

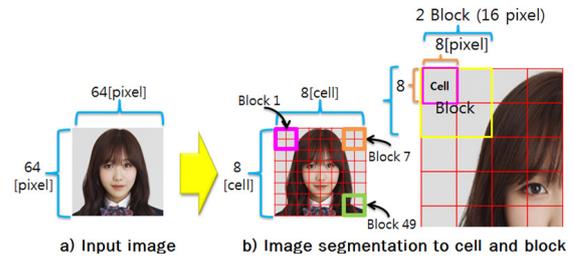


그림 2. HOG 알고리즘의 이미지 분할
Fig. 2. Image segmentation of HOG algorithm

작은 단위의 영역에 대해 위에서 구한 크기와 방향을 이용하여 각 셀 마다 히스토그램을 생성하여 셀의 벡터화를 진행한다. 여기서 히스토그램을 구성할 때 기울기의 방향 성분을 이용하여 bin으로 나타내는데 방향성분은 $0 \sim 180^\circ$ 와 $0 \sim 360^\circ$ 로 나눌 수 있다. 보통은 $0 \sim 180^\circ$ 를 20° 씩 9개의 bin으로 구성한다. 그 후 아래의 그림 3과 같이 기울기의 크기를 누적하고 block 단위로 정규화를 수행한다. 정규화하는 방법은 nom, L1-norm, L1 Sqrt, L2-norm, L2 Sqrt, L2 Hys 등이 있지만 본 논문에서는 L2-norm 방법을 사용하고 과정을 식 4-6 으로 표현하였다. 여기서 block은 2×2 [cells]로 구성되고 cell 당 $k=9$ 개의 bin이 있다고 가정한다. V_i 는 i번째 block에 대해 정규화 된 히스토그램 특징 벡터를 나타내며, V_i 는 i번째 block의 정규화 된 특징 벡터, v_c 는 cell의 특징 벡터, v_b 는 block 내 특징 벡터를 나타낸다.

$$H = [V_1, V_2, \dots, V_n]_{(n=49)} \quad (4)$$

$$V_i = \frac{vb_i}{\sqrt{\|vb_i\|^2 + \epsilon^2}} \quad (\epsilon = 1, i = 1, \dots, 49) \quad (5)$$

$$vb = [vc_1, vc_2, vc_3, vc_4], vc = [v_1, v_2, \dots, v_k] \quad (6)$$

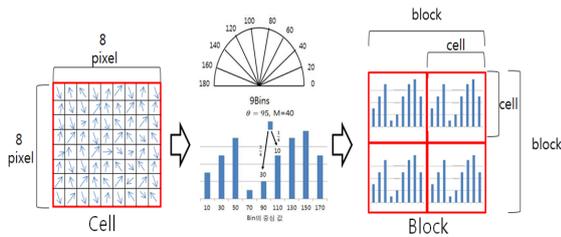


그림 3. HOG 특징과 Block 내부의 히스토그램
Fig. 3. HOG features and histogram in a block

히스토그램을 하나로 병합하여 정규화된 HOG 특징 벡터 H 를 생성한다. 각 block마다 정규화된 특징 벡터 V 는 $2 \times 2 \times 9 = 36$ 개의 차원을 가지고, 64ppi크기의 입력 이미지에서는 $7 \times 7 = 49$ 개의 block이 만들어지므로 최종적으로 $36 \times 49 = 1764$ 차원의 특징 벡터가 생성된다.

2.2 주성분 분석법(Principal Component Analysis)

이렇게 획득한 고차원의 특징벡터 집합은 신경회로망 모델의 입력 데이터로 구성하기에는 연산속도가 느리고 복잡한 구조일수록 추정할 파라미터의 수 또한 많아진다. 지능형 알고리즘에서는 높은 검출율과 빠른 인식속도를 중요한 요소로 여기기 때문에 1764개의 고차원을 저차원으로 축소시킬 필요가 있다. 이 문제점을 해결하기 위해 PCA 알고리즘을 사용하여 저차원으로 축소한다[8].

주성분 분석법은 대표적인 선형변환 특징추출 방법으로 데이터의 공분산 행렬을 이용하여 실제 데이터의 정보를 최대한 유지하며 작은 양의 특징으로 표현하는 방법으로 차원 축소 과정은 아래와 같은 단계로 진행된다.

[Step 1] 인식후보의 특징 벡터 집합 구성

$$S = \{ \Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M \} \quad (7)$$

[Step 2] 평균 특징 벡터를 계산

$$\phi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (8)$$

[Step 3] 인식후보 특징 벡터와 평균 특징 벡터와의 차이 벡터를 계산

$$\Phi_i = \Gamma_i - \phi \quad (9)$$

[Step 4] 인식후보 특징 벡터에서 공분산 행렬 계산

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \cdot \Phi_n^T = A \cdot A^T \quad (10)$$

[Step 5] M개의 고유벡터에서 가장 큰 고유값을 갖는 M'개만을 선택

[Step 6] 각 인식후보 특징과 고유벡터와의 사영을 통해 변환행렬을 획득

$$\omega_k = u_k^T (\Gamma - \phi) \quad (11)$$

$$\Omega^T = [\omega_1, \omega_2, \omega_3, \dots, \omega_{M'}] \quad (12)$$

3. FCM-based RBFNN 상반신 검출기

3장에서는 FCM-based RBFNN 패턴분류기를 학습하는 방법과 최적의 성능을 낼 수 있는 모델 구조의 설정 방법에 대해 설명한다. 신경회로망은 주어진 패턴의 반복 학습을 통하여 스스로 지식을 획득할 뿐만 아니라 패턴과 특성을 발견하기 위해 대량의 데이터를 분석할 수 있는 장점을 가지고 있어 패턴 인식이나 제어 등 많은 분야에서 응용되고 있다. 일반적인 방사형 기저함수 신경회로망(Radial Basis Function Neural Networks)은 일반적인 신경회로망의 구조를 기반으로 조건부, 결론부, 추론부로 나뉜다. 조건부에서 각 규칙들은 가우시안 함수를 활성화함수로 갖고 결론부에서는 연결가중치를 상수로 사용한다.

본 논문에서는 기존의 RBF 신경회로망과는 달리 조건부에 FCM clustering을 사용한 FCM기반 신경회로망이 사용되고 연결가중치도 확장된 개념으로 사용한다. 따라서 2장에서 추출한 HOG-PCA 특징 데이터가 입력층을 거쳐 은닉층으로 들어오면 FCM 클러스터링을 통한 이 특징의 소속행렬을 계산한다. 은닉층의 노드 수는 클러스터 수와 동일하게 결정되고 은닉층의 출력은 FCM 클러스터링의 소속정도로 대체된다. 또한 모델의 성능을 높이기 위해 차분진화 알고리즘을 사용하여 최적의 구조를 탐색한다.

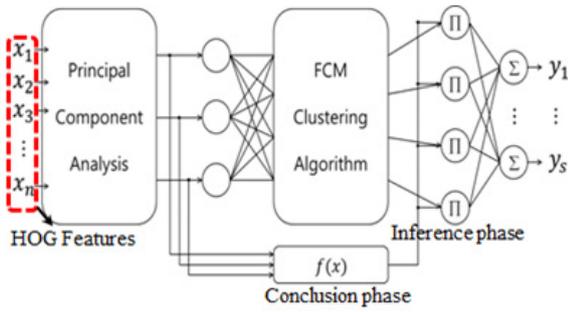


그림 4. FCM 기반 RBFNN 패턴분류기의 구조
Fig. 4. Structure of FCM-based RBFNN pattern classifier

3.1 전반부 학습 : Fuzzy C-Means Clustering

신경회로망의 전반부에서 각 규칙에 대한 적합도를 구하기 위해 본 논문에서는 RBF리는 활성화함수 대신 FCM 알고리즘을 사용하였다. 클러스터링은 비슷한 패턴과 속성 또는 형태 등의 기준을 통해서 데이터를 분류하는 무감독 학습방법으로 소프트 클러스터링과 하드 클러스터링으로 나뉜다. 클러스터링은 비유사성 측정의 목적함수가 최소가 되도록 각 클러스터의 중심점을 찾는다. 이 때 클러스터에 대한 소속정도가 가우시안 함수의 형태를 띠어 소속함수를 적합도로 사용하게 되었다. 알고리즘의 순서는 아래와 같이 진행된다.

[Step 1] 클러스터의 개수와 퍼지화계수를 선택하고, 소속함수 $U^{(r)}$ 를 초기화함

$$U^{(r)} = \left\{ \begin{array}{l} u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, \\ 0 < \sum_{k=1}^n u_{ik} < n \forall i \end{array} \right\} \quad (13)$$

[Step 2] 각 클러스터에 대한 중심 벡터를 계산

$$v_{ij} = \frac{\sum_{k=1}^n (u_{ik})^m x_{kj}}{\sum_{k=1}^n (u_{ik})^m} \quad (14)$$

[Step 3] 중심과 데이터와의 거리 계산, 새로운 소속 함수 $U^{(r+1)}$ 를 계산

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[\sum_{j=1}^l (x_{kj} - v_{ij}^{(r)})^2 \right]^{1/2} \quad (15)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}} \quad (16)$$

[Step 4] 오차가 허용범위에 도달하면 종료하고, 그렇지 않으면

[Step 2]부터 반복

$$\| U^{(r+1)} - U^{(r)} \| \leq \epsilon \quad (17)$$

3.2 후반부 학습 : Least Square Method

FCM으로 학습된 클러스터의 중심과 소속행렬로 주어진 구조에서 최적 성능을 가질 수 있는 파라미터를 결정해야 한다. 최소자승법은 근사적으로 구하려는 다항식의 해와 실제 다항식의 해에 대한 오차 제곱의 합이 최소가 되도록 다항식들의 계수를 한번에 구하는 전역 모델 학습 방법이다. 성능 평가함수를 행렬식으로 표현하면 다음의 식과 같다.

$$Q = \sum_{i=1}^c (Y - X_i A_i)^T (Y - X_i A_i) \quad (18)$$

A_i 는 추정하고자 하는 i 번째 다항식의 계수이고, Y 는 출력데이터이다. X_i 는 i 번째 지역 모델의 계수를 추정하기 위한 입력 데이터 행렬을 의미하며 선형식일 경우 다음과 같이 정의된다.

$$X_i = \begin{bmatrix} u_{11} & \dots & u_{c1} & x_{11}u_{11} & \dots & x_{k1}u_{c1} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ u_{1m} & \dots & u_{cm} & x_{1m}u_{1m} & \dots & x_{km}u_{cm} \end{bmatrix}, \quad (19)$$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}, \quad A = [a_{10}, \dots, a_{c0}, a_{11}, \dots, a_{ck}]^T$$

m 은 전체 데이터의 수, k 는 입력변수의 수, c 는 규칙 수를 나타낸다. i 번째 규칙에 대한 다항식 연결가중치의 계수는 아래의 식에 따라 구하고, 계수행렬 A 는 식 18과 같이 역행렬을 계산하여 구하거나 확장행렬을 구하여 가우스소거법에 의해 구할 수 있다.

$$A_i = (X_i^T X_i)^{-1} X_i^T Y \quad (20)$$

3.3 최적의 구조 결정 : Differential Evolution

차분진화 알고리즘은 1995년 Ken Price와 Rainer Storm에 의해 소개된 알고리즘으로 널리 사용되고 있는 유전 알고리즘과 유사한 연산과정을 갖지만 연산 시간이 빠르고 제어 파라미터가 적으면서 다른 최적화 기법들에 비해 뛰어나다는 장점이 있다. 차분진화 알고리즘은 초기 개체군을 이루는 개체를 샘플링하고 교배(crossover), 변이(mutation), 선택(selection) 과정을 거쳐서 fitness가 개선되는 새로운 개체들을 추출해낸다. 알고리즘의 과정은 아래와 같이 진행된다.

[Step 1] 초기집단 생성 (랜덤 값으로 μ 개의 개체를 초
기화, 각 개체는 n 개의 목적 변수로 구성)

$$P(t) = a_1(t), a_2(t), \dots, a_\mu(t) \quad (21)$$

[Step 2] 집단내의 모든 개체의 목적함수를 평가

$$\Phi(t) = \Phi(a_1(t)), \dots, \Phi(a_\mu(t)) \quad (22)$$

[Step 3] 모든 개체($i=1, \dots, \mu$)에 대해서 차분 변화를 위한 개체
 a_{r1}, a_{r2}, a_{r3} 를 선택하여 교배용 벡터 $v(t)$ 를 만들고
이를 교배 대상과 교배

$$v_i(t) = a_{r3}(t) + F \cdot (a_{r2}(t) - a_{r1}(t)) \quad (23)$$

$$x'_i(t) = v_i(t) \times a_i(t) \quad (24)$$

[Step 4] 모든 개체의 목적함수를 평가

[Step 5] 종료조건을 확인하고 만족되지 않으면 $t = t + 1$ 으로
하고 [Step 3]부터 반복

이를 통해 최적의 FCM 클러스터링의 클러스터 개수와
퍼지화계수와 RBF 신경회로망 결론부의 다항식의 종류를 찾는다.

4. 시뮬레이션 및 결과

HOG-PCA 특징을 이용한 상반신 검출 시스템의 실험을 수행하기
위해 학습데이터는 상반신 영역을 중심으로 정면 이외에도 측면과
후면에 대한 상반신 180장, Non-Person 4000장으로 구성하였다.
데이터는 3 분류로 나누어 Training(50%), Validation(30%),
Testing(20%)로 분할하여 실험하였다. 이미지들은 모두 64x64 크기로
맞췄기 때문에 HOG 특징벡터는 1764 차원을 얻게 되었고 PCA
를 통해 75차원으로 축소하였다. 자세한 파라미터 설정은 표 1
에 나타내었다. 표 1의 tuned values는 최적화 알고리즘으로 찾은
파라미터로 최적의 모델 구조를 나타내었고 표 2에는 최적화
알고리즘의 최종 결과와 최적화하지 않았을 때의 성능을 검출율과
정확도로 나타낸다. 또한 실험에 대한 다른 분류기와 비교를 위해
SVM의 분류 성능에 대해서도 표기하였다. RBFNN에 대한 성능은
5-fold Cross Validation을 하여 평균과 표준편차로 나타내었다.
분류율(Classification Rate)은 식 25로 계산하였고, 모델의 정확도는
MSE(Mean Square Error) 함수를 이용하여 학습데이터에 대해서는
PI, 검증데이터에 대해서는 VPI 그리고 테스트데이터에 대해서는
EPI로 표현하였다.

$$CR [\%] = 100 \times \left(1 - \frac{N_{\text{false}}}{N_{\text{total}}} \right) \quad (25)$$

표 1. DE 알고리즘의 튜닝 파라미터들과 탐색 범위
Table 1. Initial and tuned parameters of DE algorithm and search range

Parameter		Value	
DE	No. of generations	30	
	Vector size	30	
Parameter		Initial values	Tuned values
Search range	No. of clusters	[2 10]	3
	Fuzzification coefficient	[1, 1 3, 0]	2, 1380
	Type of polynomial	1, Linear 2, Quadratic	1, Linear

표 2. RBFNN과 SVM 패턴분류기의 성능
Table 2. Performance of RBFNN pattern classifier

Classifier	No. of inputs by PCA	No. of clusters (kernel)	Training		Validation		Testing	
			CR	PI	CR	VPI	CR	EPI
SVM[9]	1764	Linear	100	-	-	-	97.44	-
		Quadratic	100	-	-	-	98.00	-
RBFNN without optimization	75	2	98.80	0.0958	-	-	97.83	0.1125
		3	98.91	0.0824	-	-	98.70	0.1322
		5	99.67	0.0511	-	-	97.83	0.2168
RBFNN with optimization	75	3	99.86 ±0.03 38	0.0211 ±0.00 20	99.19 ±0.24 19	0.0554 ±0.00 35	99.28 ±0.34 65	0.0632 ±0.00 62

최적화 되지 않은 분류기(without optimization)와 최적화된
분류기(with optimization)의 축소된 입력변수는 동일하게
사용하였고 수많은 실험 결과를 통해 입력은 성능이 가장 좋게
나왔던 75차원을 선택하였다. 그리고 최적화되지 않은 분류기에서는
퍼지화계수 2.0과 다항식은 Linear로 고정하였다. 최적화하지
않았을 때, 클러스터 수를 증가시킬수록 과적합(Overfitting)되어
Testing 성능이 떨어지는 것을 확인할 수 있다. 반면에 최적화하였을
때는 DE 알고리즘을 이용하여 최적의 조건을 찾기 때문에 최적화를
사용했을 경우의 성능이 그렇지 않았을 경우보다 좋게 나오는 것을
확인할 수 있었다.

분류기를 통해서 입력된 이미지에서 상반신을 검출하기
위해서 Window Sliding Search 방식을 사용한다. 이미지 내에
검출하기 위한 대상의 크기는 알 수 없기 때문에 작은 윈도우부터
큰 윈도우까지 탐색 윈도우의 크기를 1.2배씩 증가하며 전 구역을
탐색한다. 아래의 그림은 여러 크기의 윈도우를 이동시키며 상반신
후보들을 확보하는 과정을 나타낸다.

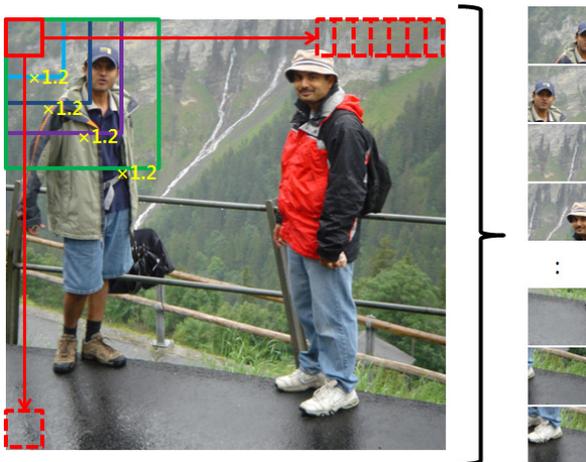


그림 5. 윈도우 슬라이딩 방식의 탐색
Fig. 5. Searching to window sliding

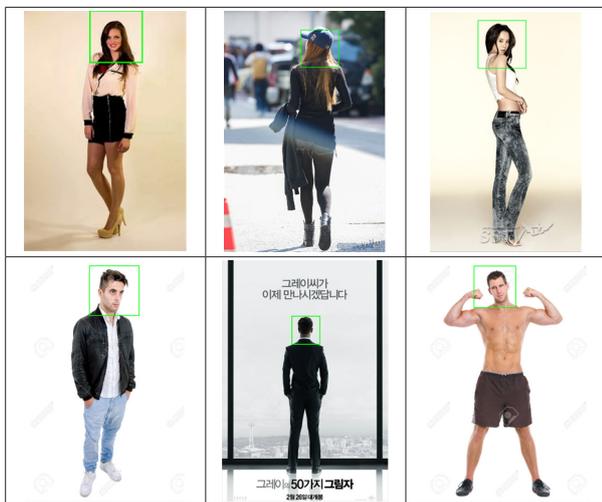
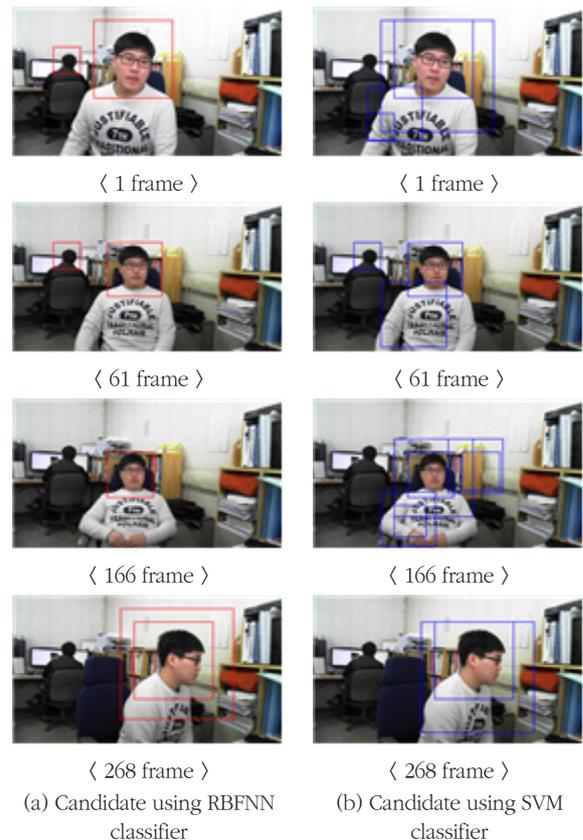


그림 6. 다양한 상황에서의 상반신 검출
Fig. 6. Upper body detection in diverse situation

슬라이딩 기법을 통해 상반신 검출 시스템의 성능을 검증하기 위해 이미지와 동영상을 이용하여 실험하였다. 실험 이미지는 정면과 후면, 측면의 이미지로 테스트하였다.

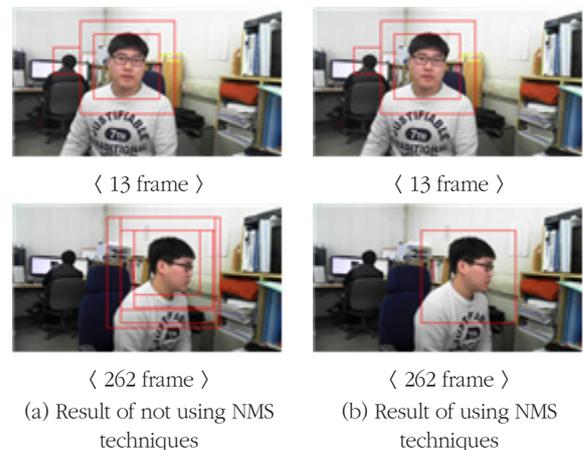
그림 6은 이미지를 이용한 실험 결과로 앞모습 이외에 뒷모습과 옆모습을 하고 있는 객체들도 성공적으로 검출된 것을 확인할 수 있었다. 단정한 머리를 한 남성의 이미지들로 실험을 하면 상반신 영역에 뚜렷한 기울기를 얻을 수 있지만 일반적으로 긴 머리를 하고 있는 여성의 경우 남성과는 다른 기울기를 가지고 있다. 이를 개선하기 위해서 남성보다 여성의 이미지에 치중하여 학습데이터를 구성하였고 위의 결과 이미지처럼 성공적으로 검출하였다.

동영상을 이용한 실험에서 신경회로망과의 비교를 위해 SVM 패턴분류기의 결과를 추가하였다. SVM은 Matlab 2014a에서 제공하는 내장함수를 사용하였으며, 커널은 Linear와 Quadratic을 사용하였고 입력변수는 1764차원의 벡터를 그대로 사용하였다.



(a) Candidate using RBFNN classifier (b) Candidate using SVM classifier

그림 7. 동영상을 이용한 상반신 검출 결과
Fig. 7. Results of upper body detection using video



(a) Result of not using NMS techniques (b) Result of using NMS techniques

그림 8. NMS 기법에 대한 결과
Fig. 8. Results about NMS techniques

그림 7에서 좌측 이미지는 RBFNN 패턴분류기를 통해서 윈도우 슬라이딩 탐색으로 검출된 후보영역을 표시하였고 우측의 이미지는 SVM분류기를 통한 후보영역을 표시하였다. SVM의 결과를 보면 166 frame에서 가장 오검출이 많이 되었지만 268 frame에서는 RBFNN 과 동일하게 상반신을 찾아내기도 하였다. 166 frame에서 우측에 있는 객체의 뒷모습을 검출하지 못한 이유는 어깨너머 모니터에

작업으로 인해 검은 영역 때문에 추출되지 않은 것으로 확인된다. 전반적으로 SVM의 결과보다 제안된 분류기의 결과가 오검출이 적은 것을 볼 수 있다. 그림 7에 표시된 상반신 영역들은 Non Maximum Suppression을 통해 선별된 대표적인 후보들로 중복되는 영역들 중에서 높은 Score를 가지는 영역을 기반으로 포개진 정도를 판단하여 친 영역을 제거해 준다. RBFNN에서의 Score는 모델의 정확도로 선정하였고, SVM에서는 서포트 벡터부터와의 거리를 Score로 정하였다. 아래의 그림 8은 NMS를 하지 않았을 때의 Positive 영역과 NMS를 통해 추출된 대표 영역을 표시한 결과이다.

5. 결론 및 향후 연구

본 논문에서는 HOG-PCA 특징을 통해서 최적화된 FCM-based RBFNNs 패턴분류기를 이용한 객체의 상반신 검출 시스템을 제안하였다. 성능을 평가하기 위해 다양한 이미지와 수원대학교 연구실에서 촬영한 영상으로 실험을 진행하였다. 상반신 영역을 찾기 위해 윈도우 슬라이딩 탐색 기법을 이용하였지만 전 구역을 작은 윈도우부터 큰 윈도우까지 확장하며 탐색하기 때문에 탐색시간이 매우 오래 걸린다는 단점이 있다. 하지만 기존에 사용했던 INRIA 보행자 이미지에이터를 사용했을 때보다 성능에서도 검출된 결과에서도 우수한 것을 확인할 수 있었다.

향후에는 낮은 검출 속도를 개선하여 배경학습 또는 새로운 검출 방법을 이용하여 속도를 높이기 위한 연구를 진행할 예정이다.

References

- [1] Ran Choi, "A Study on Applying MCT Algorithm to Detection of Pedestrian", Ph. D. Dissertation, Hanshin University, Hanshin, 2013.
- [2] Dalal and B. Triggs, "Histograms of oriented gradients for human detection" *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 886-893, 2005
- [3] S. B. Roh, S. K. Oh, and W. Pedrycz. "Design of fuzzy radial basis function-based polynomial neural networks." *Fuzzy sets and systems* Vol. 185, pp. 15-37, December 2011
- [4] S-K, Oh, W-D, Kim, and W. Pedrycz, "Polynomial based radial basis function neural networks (P-RBFNNs) realized with the aid of particle swarm optimization," *Fuzzy Sets and Systems*, Vol. 163, No. 1, pp. 54-77, 2011
- [5] J-Y, Kim, C-J, Park and S-K, Oh, "Design & Implementation

- of Pedestrian Detection System Using HOG-PCA Based pRBFNNs Pattern Classifier," *The Transactions of the Korean Institute of Electrical Engineers* Vol. 64, No. 7, pp. 1064 ~ 1073, 2015
- [6] W. K. Kim, S. K. Oh, H. K. Kim, "A Study on Feature Selection In Face Image Using Principal Component Analysis and Particle Swarm Optimization Algorithm", *KIEE*, Vol. 58, No. 12, pp. 2511-2519, 2009
- [7] J. H. Baek, J. S. Kim, C. Y. Yoon, E. T. Kim, "Part-based Hand Detection Using HOG", *Korean Institute of Intelligent Systems*, Vol. 23, No. 6, pp. 551-557, 2013
- [8] S. K. Oh, S. H. Yoo and W. Pedrycz, "Design of face recognition algorithm using PCA -LDA combined for hybrid data pre-processing and polynomial-based RBF neural networks : Design and its application", *Expert Systems with Applications*, Vol. 40, pp. 1451-1466, 2013
- [9] Mathworks, "Train support vector machine classifier", <http://kr.mathworks.com/help/stats/svmtrain.html>

저 자 소 개



김 선 환(Sun-Hwan Kim)
2015년 : 수원대학교 전기공학과 졸업
2015년~현재 : 동 대학원 석사과정

관심분야 : Fuzzy, Neural Network, Machine Learning, Image Processing, Pattern Recognition
Phone : +82-31-222-6544
E-mail : ksh0301@suwon.ac.kr



오 성 권(Sung-Kwon Oh)
1981년 : 연세대학교 전기공학사
1983년~1989년 : 금성산전 연구소(선임연구원)
1993년 : 연세대학교 전기공학과 공학박사
1996년~1997년 : 캐나다 Manitoba 대학전기 및 컴퓨터 공학과 Post-Doc
1993년~2004년 : 원광대학교 전지전자 및 정보 공학부 교수

2005년~ 현재 : 수원대학교 전기공학과 교수

2002년~ 현재 : 대한전기학회, 퍼지 및 지능시스템학회 편집위원

2013년~ 현재 : Information Sciences 편집위원

관심분야 : Fuzzy System, Fuzzy-Neural Network, Automatic System, Advanced Computational Intelligence, Intelligent Control

Phone : +82-31-222-6544

E-mail : ohsk@suwon.ac.kr



김진율(Jin-Yul Kim)

1986년 : 서울대학교 전자공학과 졸업,

1988년 : 한국과학기술원 전기 및 전자공학과
공학 석사

1993년 : 한국과학기술원 전기 및 전자공학과
공학박사

1994~현재 : 수원대학교 전자공학과 교수

관심분야 : 신호처리시스템 설계, 영상내 객체 추적

Phone : +82-31-220-2323

E-mail : jykim@suwon.ac.kr